DOI:10.16410/j.issn1000-8365.2026.5272

基于神经网络的镍基多晶合金高温压缩流变应力预测

沈文涛[1,2],上官赞鹏[3],刘　强[1,2,3],巫荣海[3,4],罗恒军[1,2],郭良刚[3],李　恒[3]

(1. 中国第二重型机械集团德阳万航模锻有限责任公司,四川 德阳 618000;2. 二重集团德阳航空科技有限公司,四川 德阳 618000;3. 西北工业大学 凝固技术全国重点实验室,陕西 西安 710072;4. 西北工业大学深圳研究院,广东 深圳 518057)

摘　要:为模拟镍基多晶合金热锻过程的压缩行为,开展变形温度 880 和 1 030 ℃、加载速率 3 和 18 mm/s 条件下的热压缩实验。为预测热压缩过程中的复杂流变行为,基于材料在不同变形机制(加工硬化、动态回复、动态再结晶)主导下的物理特征,构建了多分支融合神经网络(multi-branch fusion neural network, MBFNN)模型。该模型通过对应变、应变速率和温度效应进行分支解耦表达,并在融合层中重新组合三者的非线性关联进行预测。为评估模型预测效果,同时建立了传统全连接神经网络(fully connected neural network, FCNN)和门控循环单元神经网络(gated recurrent unit, GRU)作为对照模型,与 MBFNN 模型预测结果进行对比分析。结果表明,MBFNN 模型在预测精度、曲线形貌保持性及物理一致性方面均显著优于 FCNN 与 GRU 模型,能够准确再现加工硬化峰值、动态回复平缓段以及动态再结晶诱导的应力软化等多阶段流变特征;而 FCNN 与 GRU 在软化段和峰值区的拟合能力相对不足,无法充分反映变形机制的多阶段演化规律。

关键词:多晶高温合金;热压缩;流变曲线;神经网络

中图分类号:TG132.3+2　　**文献标识码**:A　　**文章编号**:1000-8365(2026)10-1175-08

Predicting the High-temperature Compressive Flow Stress of Nickel-based Polycrystalline Superalloys by a Neural Network

SHEN Wentao[1,2], SHANGGUAN Zanpeng[3], LIU Qiang[1,2,3], WU Ronghai[3,4], LUO Hengjun[1,2], GUO Lianggang[3], LI Heng[3]

(1. China National Erzhong Group Deyang Wanhang Die Forging Co., Ltd., Deyang 618000, China; 2. Erzhong Group (Deyang) Aviation Science & Technology Co., Ltd., Deyang 618000, China; 3. State Key Laboratory of Solidification Processing, Northwestern Polytechnical University, Xi'an 710072, China; 4. Shenzhen Research Institute of Northwestern Polytechnical University, Shenzhen 518057, China)

Abstract: To simulate the compressive behavior of nickel-based polycrystalline alloys during hot forging, hot compression experiments were conducted at deformation temperatures of 880 and 1 030 ℃ at loading rates of 3 and 18 mm/s, respectively. To predict the complex rheological behavior during hot compression, a multi-branch fusion neural network (MBFNN) model was constructed on the basis of the physical characteristics of the material under different deformation mechanisms (work hardening, dynamic recovery, and dynamic recrystallization). This model decouples the effects of strain, strain rate, and temperature into separate branches and then recombines their nonlinear interactions in a fusion layer for prediction. To evaluate the model's predictive performance, traditional fully connected neural network (FCNN) and gated

收稿日期:2025-12-10

基金项目:德阳市科技计划项目-旌湖实验室重点研发专项(2023GTFD001);广东省基础与应用基础研究基金自然科学基金面上项目(2024A1515010578);凝固技术全国重点实验室开放课题(2025-TS-11)

作者简介:沈文涛,1981 年生,博士,高级工程师.主要从事高温合金科学与技术研究.Email: shenwentao@wh.sinomach-ez.cn

通信作者:刘　强,1990 年生,博士,高级工程师.研究方向为先进金属结构材料及其精确热成形技术.Email: liuqiang@wh.sinomach-ez.cn

巫荣海,1989 年生,博士,副教授.研究方向为高温材料多尺度表征与计算.Email: ronghai.wu@nwpu.edu.cn

引用格式:沈文涛,上官赞鹏,刘强,巫荣海,罗恒军,郭良刚,李恒.基于神经网络的镍基多晶合金高温压缩流变应力预测[J].铸造技术,2026,47(10):1175-1182.

SHEN W T, SHANGGUAN Z P, LIU Q, WU R H, LUO H J, GUO L G, LI H. Predicting the high-temperature compressive flow stress of nickel-based polycrystalline superalloys by a neural network[J]. Foundry Technology, 2026, 47(10): 1175-1182.

中国知网　https://www.cnki.net

recurrent unit (GRU) models were also established as controls for comparative analysis with the MBFNN model. The results show that the MBFNN model significantly outperforms both the FCNN and the GRU models in terms of prediction accuracy, curve morphology preservation, and physical consistency. It accurately reproduces multi-stage rheological features such as work hardening peaks, steady-state stages of dynamic recovery, and stress softening induced by dynamic recrystallization. In contrast, the FCNN and GRU models have relatively insufficient fitting capabilities in the softening stage and peak region and fail to fully reflect the multi-stage evolution of deformation mechanisms.

Key words: polycrystalline superalloy; high-temperature compression; flow curve; neural network

高温压缩条件下金属材料通常呈现由加工硬化、动态回复到动态再结晶依次主导的多阶段非线性流变行为，其应力–应变响应对温度、应变速率及微观组织演化高度敏感，预测难度大[1-3]。传统的物理本构模型(如 Arrhenius 型[4]、Modified Johnson-Cook 型[5]、Fields-Bachofen 型[6])往往依赖大量经验参数[7]，需要针对不同阶段采用分段或嵌套形式进行拟合，不仅参数耦合度高、标定过程复杂且易陷入局部最优，而且在软化段、峰值区及不同变形机制交替处常出现拟合不足[8]。因此，构建能够同时捕捉多阶段变形特征、减少人为假设并具备更强泛化能力的数据驱动模型具有重要意义。

马斌等[9]通过优化的反向传播神经网络、支持向量机、随机森林对 7050 铝合金高温流动应力进行了预测；林启权等[10]通过优化的反向传播神经网络对 DP980 钢板的流动应力应力进行了预测；卢旭等[11]使用神经网络对钨合金冲击载荷下的流动应力进行预测。而姜健等[12]通过神经网络辅助理论本构模型预测高熵合金高温流动应力行为；胡鹏飞等[13]基于神经网络对 TC23 合金高温流动行为进行预测；滕海灏等[14]通过神经网络对 Ti-55511 合金等温压缩过程流动应力进行预测。此外，张国栋等[15]基于粉末冶金高温合金盘件中夹杂物的尺寸和位置等特征数据，分别构建了支持向量回归、随机森林、梯度提升机、核岭回归和套索回归等机器学习模型，用于预测盘件低周疲劳寿命。刘楠等[16]主要采用了蚁群算法优化的 BP 神经网络，其中蚁群算法用于优化网络结构，BP 神经网络用于预测铜基复合材料的力学与电学性能。李佩璇等[17]围绕固体润滑材料研发，总结了集成计算材料工程在理论建模、原子尺度模拟、高通量计算与数据驱动机器学习中的应用，系统评述了其在润滑和耐磨性能设计中的作用。周长璐等[18]综述了蠕变断裂寿命预测的主要方法，包括时间–温度参数法、蠕变本构模型、声发射技术以及机器学习方法，并分析了各类方法的优势、局限与发展方向。邓钥丹等[19]主要采用了前馈神经网络作为代理模型，并结合多目标遗传算法进行全局优化，用于镍基高温合金的多目标成分设计。综上，目前应用传统神经网络构建流动应力预测模型的研究较多，而面向高温流变多阶段特征构建针对性网络架构的研究仍较为有限，并且通过整条流动应力–应变曲线对模型预测能力进行系统比较的研究也相对较少。

本文以 Inconel 718 镍基高温合金作为研究对象，在变形温度 880 和 1 030 ℃、加载速率 3 和 18 mm/s 条件下进行等温热压缩实验。在实验数据基础上，构建了一种结合材料高温变形物理特征的多分支融合神经网络 MBFNN 模型，该模型针对应变、应变速率和温度等关键变量进行分支化建模，以更好地表征其耦合作用下的复杂流变行为。同时，为全面评估所提出方法的有效性，还分别建立了传统的全连接神经网络 FCNN 和典型的时序神经网络 GRU 作为对照模型，从预测精度、曲线形貌保持性及流变机制刻画能力等方面展开系统对比，用以验证 MBFNN 在复杂高温流变行为预测中的优势。

1 实验材料及方法

1.1 实验材料与设计

实验材料为 Inconel 718 镍基多晶高温合金，主要化学成分如表 1 所示。试样为直径 8 mm、高度 12 mm 的圆柱，实验参数如表 2 所示。初始微观组织如图 1 所示，可见，初始组织基本为等轴状，取向较随机，无明显织构。

表 1 Inconel 718 镍基高温合金化学成分
Tab.1 The main chemical composition of Inconel 718 nickel–based superalloys

(mass fraction/%)

Cr	Mo	Nb	Ti	Al	C	Co	P	Ni
17.91	3.03	5.38	1.02	0.56	0.02	0.19	0.01	Bal.

1.2 流变行为

图 2 为不同热变形条件下。Inconel 718 镍基高温合金的真应力–真应变曲线。可以看出，Inconel 718 镍基高温合金的高温的流变行为显著受变形温度和应变速率的影响。应力与变形温度、应变速率和应变量呈高度非线性关系，适合采用机器学习的方法构建精确的材料本构模型。

中国知网 https://www.cnki.net

表 2 热压缩实验参数

Tab.2 Thermal compression test parameters

No.	Compression rate/(mm·s^{-1})	Deformation temperature/℃	Compression percentage/%	True strain
Exp. 1	3	880	15	0.162 5
Exp. 2	3	880	50	0.693 1
Exp. 3	18	880	15	0.162 5
Exp. 4	18	880	50	0.693 1
Exp. 5	3	1 030	15	0.162 5
Exp. 6	3	1 030	50	0.693 1
Exp. 7	18	1 030	15	0.162 5
Exp. 8	18	1 030	50	0.693 1

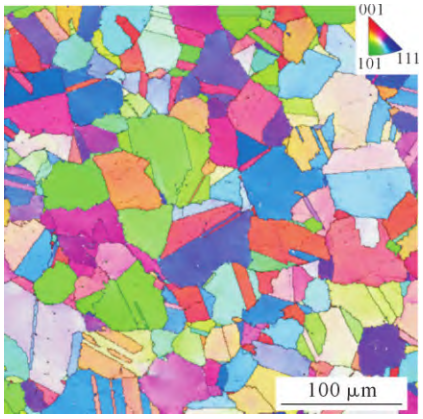


图 1 Inconel 718 镍基高温合金初始晶界取向图

Fig.1 Initial grain boundaries and orientation diagram of the Inconel 718 nickel-based superalloy

2 数据划分与模型建立

2.1 数据划分与预处理

本文所使用的数据集为图 2 显示的 8 条应力–应变曲线，第 5 条曲线数据作为测试数据，其余 7 条曲线数据作为训练数据。本文所用的特征为应变，应变速率，温度 3 个特征，应力作为目标值。在使用数据之前，需要进行预处理。应用 Min-Max 归一化方法[20]，将特征映射到[0, 1]的范围内。

$$X'=\frac{X-X_{\min}}{X_{\max}-X_{\min}} \tag{1}$$

式中，X 是一个特征，$X_{\min}$ 和 $X_{\max}$ 分别是特征 X 的最小值和最大值。为定量比较实验与预测结果，均值绝对百分比误差(mean absolute percentage error, MAPE)和决定系数(R^2)定义为[21-23]：

$$\mathrm{MAPE}=\frac{1}{n}\sum_{i=1}^{n}\frac{|f(X_i)-y_i|}{y_i} \tag{2}$$

$$R^2=1-\frac{\Sigma_{i=1}^{n}(f(X_i)-y_i)^2}{\Sigma_{i=1}^{n}(f(X_i)-\overline{f(X_i)})^2} \tag{3}$$

式中，$\overline{f(X_i)}$为实验值的均值。对于 MAPE 来说，其值越小越好。对于 R^2 来说，其值越大越好。

2.2 多分支融合神经网络

图 3 为本文设计的多分支融合神经网络结构示意图。

在单分支子网络中，对于任意一个标量输入 $x\in\mathbf{R}$(例如 $\varepsilon,\dot{\varepsilon},T$)，构造如下 3 层前馈网络：

$$h_1=\phi(W_1x+b_1),\ W_1\in\mathbf{R}^{64\times1},\ b_1\in\mathbf{R}^{64} \tag{4}$$

$$h_2=\phi(W_2h_1+b_2),\ W_2\in\mathbf{R}^{32\times64},\ b_2\in\mathbf{R}^{32} \tag{5}$$

$$s=W_3h_2x+b_3,\ W_3\in\mathbf{R}^{1\times32},\ b_3\in\mathbf{R} \tag{6}$$

式中，W_1,W_2,W_3 分别为单分支子网络中的第一、第二、第三层线性变换权重；b_1,b_2,b_3 分别为单分支子网络中的第一、第二、第三层偏置；h_1,h_2 分别为第一、二层隐含特征；s 为子网络的输出；激活函数 ϕ 为修正线性单元[24]：

$$\phi(Z)=\max(0,Z) \tag{7}$$

式中，Z 代表激活函数的输入，分别针对 3 个物理输入构造 3 套参数独立的分支网络：

$$s_\varepsilon=f_\varepsilon(\varepsilon) \tag{8}$$

$$s_{\dot{\varepsilon}}=f_{\dot{\varepsilon}}(\dot{\varepsilon}) \tag{9}$$

$$s_T=f_T(T) \tag{10}$$

式中，$f_\varepsilon(\cdot)$为主要学习应变硬化/软化随 ε 的演化特征；$f_{\dot{\varepsilon}}(\cdot)$为学习应变速率敏感性；$f_T(\cdot)$为学习温度软化对流变应力的影响。对于分支特征融合网络，将 3

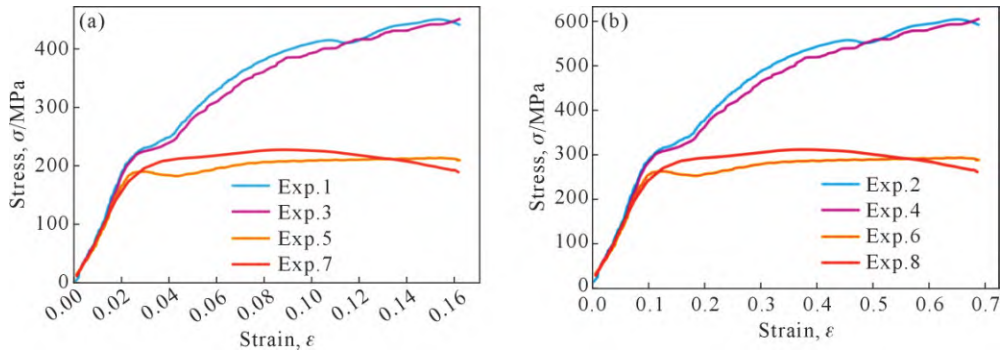


图 2 不同变形条件下的 Inconel 718 合金的真应力–真应变曲线：(a) 15%压缩量；(b) 50%压缩量

Fig.2 True strain-true stress curves of the Inconel 718 alloy under different deformation conditions: (a) 15% compression; (b) 50% compression

中国知网 https://www.cnki.net

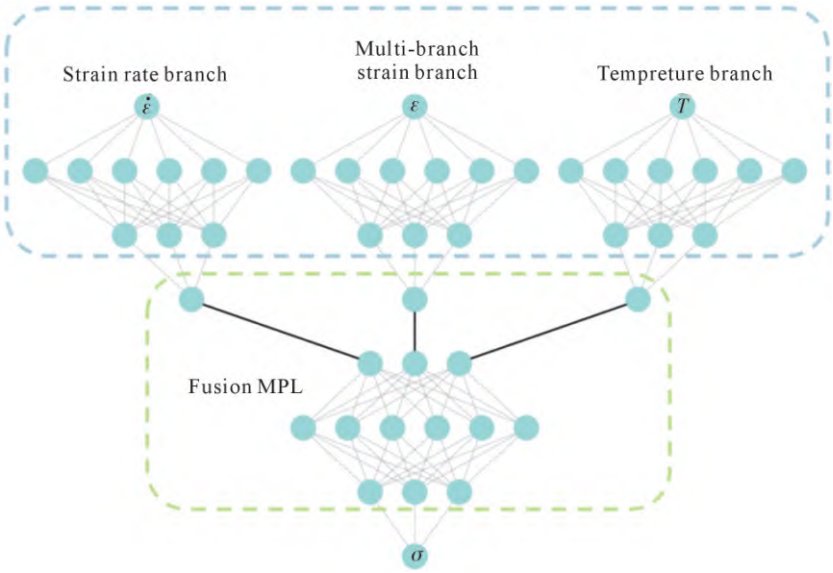


图 3 多分支融合神经网络结构示意图

Fig.3 Schematic diagram of the multi-branch fusion neural network structure

个分支输出拼接成 3 维向量：

$$z=\begin{bmatrix} s_{\varepsilon} \\ s_{\dot{\varepsilon}} \\ s_{T} \end{bmatrix} \tag{11}$$

在融合阶段，通过两层全连接网络进一步建模 3 种物理机制之间的耦合作用：

$$u_1=\phi(W_{\mathrm{f}}^{(1)}z+b_{\mathrm{f}}^{(1)}),\ W_{\mathrm{f}}^{(1)}\in\mathbf{R}^{64\times3},\ b_{\mathrm{f}}^{(1)}\in\mathbf{R}^{64} \tag{12}$$

$$u_2=\phi(W_{\mathrm{f}}^{(2)}u_1+b_{\mathrm{f}}^{(2)}),\ W_{\mathrm{f}}^{(2)}\in\mathbf{R}^{32\times64},\ b_{\mathrm{f}}^{(2)}\in\mathbf{R}^{32} \tag{13}$$

$$\sigma_{\mathrm{raw}}=W_{\mathrm{f}}^{(3)}u_2+b_{\mathrm{f}}^{(3)},\ W_3\in\mathbf{R}^{1\times32},\ b_{\mathrm{f}}^{(3)}\in\mathbf{R} \tag{14}$$

式中，$W_{\mathrm{f}}^{(1)}$、$W_{\mathrm{f}}^{(2)}$、$W_{\mathrm{f}}^{(3)}$分别为分支特征融合网络中的第一、第二、第三层线性变换权重；$b_{\mathrm{f}}^{(1)}$、$b_{\mathrm{f}}^{(2)}$、$b_{\mathrm{f}}^{(3)}$分别为分支特征融合网络中的第一、第二、第三层偏置；u_1，u_2 分别为第一、二层隐含特征；σ_{raw} 为融合网络的输出。激活函数 ϕ 为修正线性单元。

为满足流变应力物理上非负的约束，采用Softplus函数对原始输出进行映射[25]：

$$\hat{\sigma}=\mathrm{Softplus}(\sigma_{\mathrm{raw}}) \tag{15}$$

式中，$\hat{\sigma}$为最终的应力预测值。由此，多分支融合神经网络整体实现了如下映射：

$$\hat{\sigma}=f_{\theta}(\varepsilon,T,\dot{\varepsilon}) \tag{16}$$

式中，θ 为全部网络参数集合。

3 实验结果及讨论

图 4a 和 b 分别为本研究中多分支融合神经网络在训练集与测试集上的预测散点对比结果。可以看出，预测应力几乎精确落在对角线附近，其中训练集 R^2=0.998 7，测试集 R^2=0.976 8，说明模型能够稳定、准确地捕捉应力响应的全局趋势。对应的 MAPE 也保持在较低水平，进一步验证了 MBFNN 对整体应力水平的强泛化能力。图 4c 和 d 展示了 MBFNN 在应力–应变曲线层面的预测表现。对于所有曲线(图 4c)，模型能够一致性地再现加工硬化、动态回复以及动态再结晶诱导的多阶段流变特征，且与实验曲线高度吻合。对于测试曲线，模型同样能准确描述初始快速硬化段与峰值附近的应力演化，同时对软化阶段的趋势也保持了良好的拟合精度，体现了 MBFNN 捕捉变形机制演化规律的能力。

为更好对比 MBFNN 模型，训练了一个 7 层 FCNN 模型和一个 4 层 GRU 模型。FCNN 和 GRU 模型在训练批次数、据划分、种子数等方面都固定为一致。图 5 和 6 分别 FCNN 和 GRU 的表现情况。图 5a 和 c 共同说明 FCNN 在训练集上具有较高的拟合能力。对角线散点几乎完全贴合理想线，指标达到 R^2=0.999 3、MAPE=2.49%，表明模型成功学习了实验应力–应变的主要演化规律。图 5b 和 d 展示了 FCNN 在未参与训练的工况(第 5 条曲线)上的预测表现。相比训练集，散点图中偏离对角线的点明显增多，指标下降为 R^2=0.964 8、MAPE=6.42%。对应的完整曲线显示，FCNN 虽能较准确预测初始加工硬化段，但在软化阶段出现明显高估，无法正确反映动态再结晶的软化行为，说明模型预测方面的泛化能力有限。

图 6a 表明 GRU 模型在训练集上的预测与真实应力几乎完全重合(R^2=0.999 7，MAPE=1.35%)，说明模型成功学习了应力–应变内在规律。图 6c 对比 7 条训练曲线的应力–应变关系，GRU 能准确再现屈服、加工硬化以及后期软化的全过程，体现出优秀的

中国知网 https://www.cnki.net

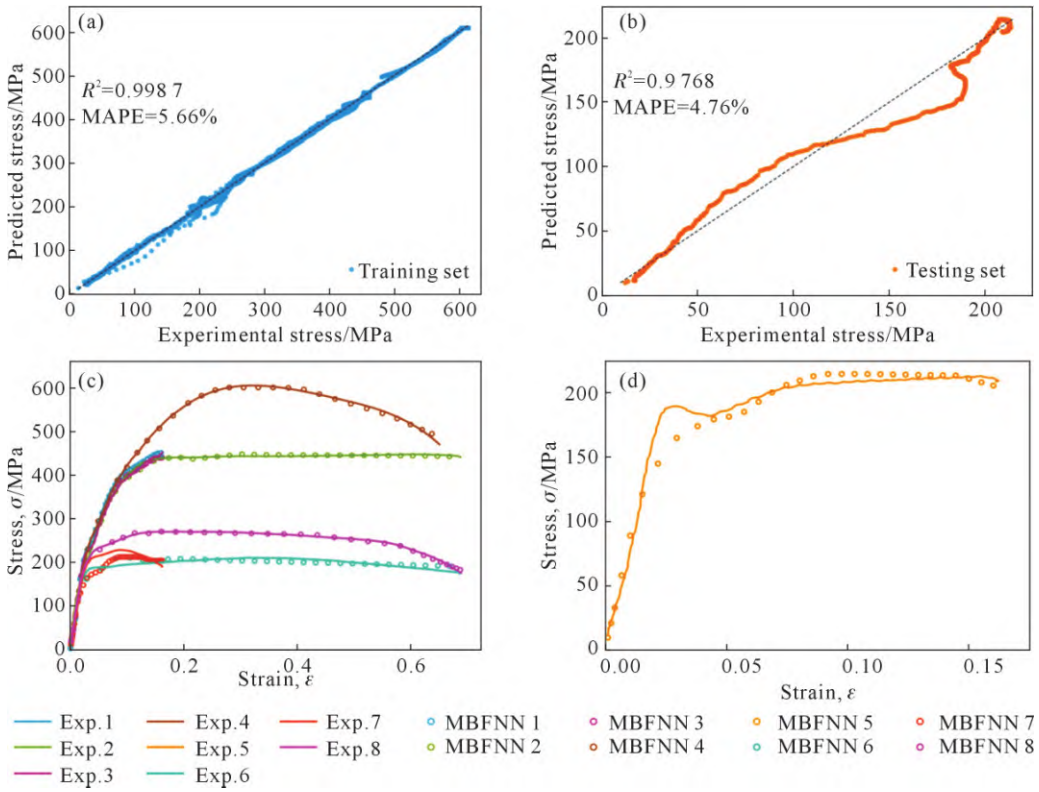


图 4　多分支融合神经网络训练与测试效果：(a) 训练集；(b) 测试集；(c) 训练集应力–应变曲线对比；(d) 测试集应力–应变曲线对比

Fig.4　Training and testing results of the multi-branch fusion neural network: (a) training set; (b) testing set; (c) comparison of stress-strain curves in the training set; (d) comparison of stress-strain curves in the testing set

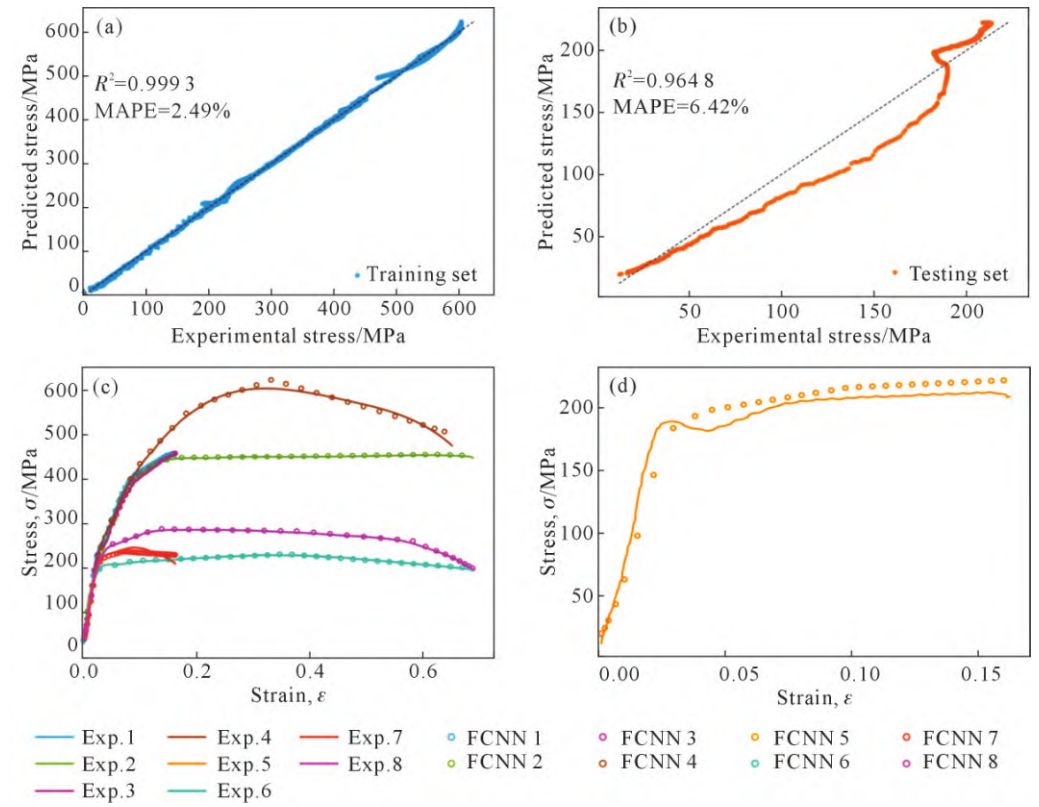


图 5　全连接神经网络训练与测试效果：(a) 训练集；(b) 测试集；(c) 训练集应力–应变曲线对比；(d) 测试集应力–应变曲线对比

Fig.5　Training and testing results of the fully connected neural network: (a) training set; (b) testing set; (c) comparison of stress-strain curves in the training set; (d) comparison of stress-strain curves in the testing set

中国知网　https://www.cnki.net

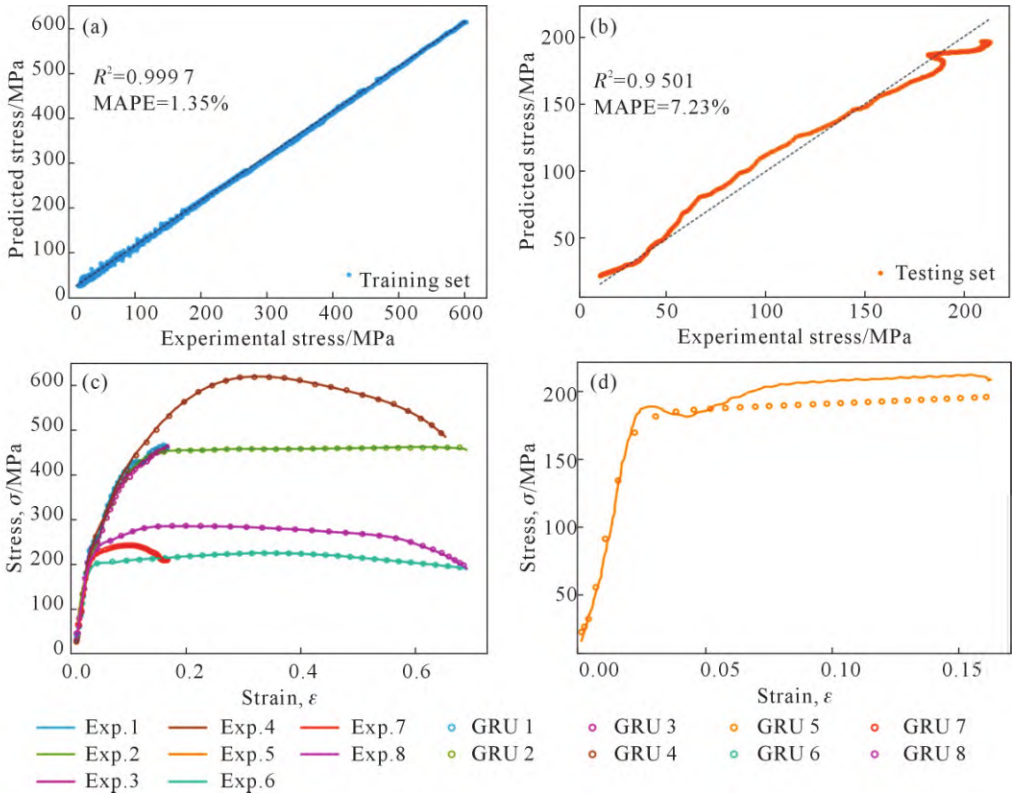


图 6 门循环单元训练与测试效果：(a) 训练集；(b) 测试集；(c) 训练集应力应变曲线对比；(d) 测试集应力–应变曲线对比

Fig.6 Training and testing results of the recurrent gate unit: (a) training set; (b) testing set; (c) comparison of stress-strain curves in the training set; (d) comparison of stress-strain curves in the testing set

拟合能力和稳定性。图 6b 显示模型在独立测试曲线上仍保持良好精度(R^2=0.950 1，MAPE=7.23%)。图 6d 展示的完整应力–应变响应进一步揭示了 GRU 在软化阶段的预测局限性。虽然 GRU 能够较准确地捕捉初始弹性段与加工硬化阶段的演化趋势，但在峰后软化区域，其预测曲线明显偏离实验值，表现出与 FCNN 类似的欠预测特征。

4 结论

(1)在测试集上，MBFNN 获得最优的 R^2 和MAPE 指标，散点预测结果高度贴近对角线，说明模型能够稳定捕捉应力响应的全局趋势。相比之下，FCNN 和 GRU 的预测散点偏离更明显，表现出不同程度的泛化不足。

(2)MBFNN 可同时复现加工硬化峰值、动态回复平稳段以及动态再结晶诱导的软化特征，完整曲线与实验高度一致，具有显著的物理一致性。而FCNN 与 GRU 在峰值区和软化段均出现偏差，尤其在 DRX 软化阶段表现出明显欠拟合，难以反映真实的组织演化规律。

(3)MBFNN 通过分别学习应变、应变速率和温度对应的特征分布，并在融合阶段建模三者的非线性耦合关系，使得模型能够更好地捕捉材料变形机制主导的关键特征变化，从而在曲线重建与细节保持能力上显著优于对照模型。

参考文献：

[1] 王瀚岑，毛虎平，裴海祥，薛臣，亓岳岩. 奥氏体不锈钢高温压缩曲线及组织分析[J]. 铸造技术，2018, 39(10): 2367-2368, 2371.
WANG H C, MAO H P, PEI H X, XUE C, QI Y Y. High-temperature compression curves and microstructures of austenitic stainless steels[J]. Foundry Technology, 2018, 39(10): 2367-2368, 2371.

[2] 徐健清，谭静. 锻态 TB9 钛合金高温压缩行为数值模型研究[J]. 铸造技术，2018, 39(6): 1305-1308.
XU J Q, TAN J. Study on numerical model of high temperature compression behavior of forged TB9 titanium alloy[J]. Foundry Technology, 2018, 39(6): 1305-1308.

[3] 王文彬. 基于热压缩模拟实验的 800H 合金高温变形行为研究[J]. 铸造技术，2014, 35(7): 1387-1389.
WANG W B. Study on high temperature deformation behavior of 800H alloy based on heat compression simulation experimental[J]. Foundry Technology, 2014, 35(7): 1387-1389.

[4] 王清玲，李建华. F40MnV 钢高温流动应力的预测[J]. 铸造技术，2014, 35(7): 1505-1507.
WANG Q L, LI J H. Prediction of high-temperature flow stress on steel F40MnV[J]. Foundry Technology, 2014, 35(7): 1505-1507.

[5] 杜康，杨来侠，黄宁，徐超. 选区激光熔化 Inconel 625 镍基合金 Modified Johnson-Cook 模型建立及流动应力预测[J]. 应用激光，2024, 44(5): 1-10.
DU K, YANG L X, HUANG N, XU C. Modified Johnson-Cook model establishment and flow stress prediction of Inconel 625 nickel-based alloy melted by selective laser[J]. Applied Laser, 2024,

中国知网 https://www.cnki.net

44(5): 1-10.

[6] 牛勇，洪志强，王耀奇. 基于多种唯象型模型对 Ti6Al4V 两相区流动应力的预测及比较[J]. 塑性工程学报，2022, 29(12): 106-117.
NIU Y, HONG Z Q, WANG Y Q. Prediction and comparation of flow stress of Ti6Al4V in two phases region based on multiple phenomenological models[J]. Journal of Plastic Engineering, 2022, 29(12): 106-117.

[7] 文超，孙前江，徐浩，马鑫. 基于 Arrhenius 模型和修正 Johnson-Cook 模型的 TC21 钛合金流动应力预测[J]. 塑性工程学报，2023, 30(11): 82-90.
WEN C, SUN Q J, XU H, MA X. Flow stress prediction of TC21 titanium alloy based on Arrhenius model and modified Johnson-Cook model[J]. Journal of Plastic Engineering, 2023, 30(11): 82-90.

[8] 李全，金朝阳. 采用改进和优化的 Zerilli-Armstrong 本构模型预测 AZ80 镁合金的高温流动应力[J]. 中国有色金属学报，2021, 31(8): 2091-2100.
LI Q, JIN C Y. Prediction of high temperature flow stress of AZ80 magnesium alloy by using modified and optimized Zerilli-Armstrong constitutive models[J]. The Chinese Journal of Nonferrous Metals, 2021, 31(8): 2091-2100.

[9] 马斌，梁强，贾艳艳，徐永航. 基于 BPNN、SVR 和 RF 模型的7050合金高温流动应力预测[J]. 材料热处理学报，2023, 44(3): 196-204.
MA B, LIANG Q, JIA Y Y, XU Y H. Prediction of high temperature flow stress of 7050 aluminum alloy based on BPNN, SVR and RF models[J]. Journal of Materials Heat Treatment, 2023, 44(3): 196-204.

[10] 林启权，卜根，王镇柱，董文正，王凯. 基于 BP 神经网络的DP980 钢板本构关系[J]. 塑性工程学报，2022, 29(8): 139-144.
LIN Q Q, BU G, WANG Z Z, DONG W Z, WANG K. Constitutive relationship of DP980 steel sheet based on BP neural network[J]. Journal of Plastic Engineering, 2022, 29(8): 139-144.

[11] 卢旭，赖修文. 基于神经网络预测钨合金冲击载荷下的流动应力[J]. 机械工程师，2022(9): 48-52, 56.
LU X, LAI X W. Prediction of flow stress in tungsten heavy alloy under dynamic loading by artificial neural networks[J]. Mechanical Engineer, 2022(9): 48-52, 56.

[12] 姜健，胡涛，庄三少，冯淼林. 神经网络辅助理论本构模型预测高熵合金高温流动应力行为[J]. 固体力学学报，2024, 45(3): 302-312.
JIANG J, HU T, ZHUANG S S, FENG M L. A neural network-assisted theoretical constitutive model to predict the high temperature flow behavior of high-entropy alloys[J]. Chinese Journal of Solid Mechanics, 2024, 45(3): 302-312.

[13] 胡鹏飞，李开勇，尹国杰. 基于神经网络预测的 TC23 合金高温流动行为精确仿真[J]. 塑性工程学报，2021, 28(12): 132-139.
HU P F, LI K Y, YIN G J. Accurate simulation of hot flow behavior of TC23 titanium alloy based on neural network prediction[J]. Journal of Plastic Engineering, 2021, 28(12): 132-139.

[14] TENG H H, XIA Y F, SUN T, ZHENG D Y, CHEN L. Flow stress prediction of near-β Ti-55511 alloy during isothermal compression based on modified arrhenius model and BP-ANN model[J]. Rare Metal Materials and Engineering, 2023, 52(3): 823-833.

[15] 张国栋，苏宝龙，廖玮杰，王晓峰，邹金文，袁睿豪，李金山. 机器学习在高温合金粉末盘构件疲劳寿命预测中的应用[J]. 铸造技术，2022, 43(7): 519-524.
ZHANG G D, SU B L, LIAO W J, WANG X F, ZOU J W, YUAN R H, LI J S. Prediction of fatigue life of powder metallurgy superalloy disk via machine learning[J]. Foundry Technology, 2022, 43(7): 519-524.

[16] 刘楠，郭青成，马麟趾，王嘉琦. 基于机器学习的高强高导 Cu 基复合材料力-电性能统一预测模型研究[J]. 铸造技术，2024, 45(1): 44-49.
LIU N, GUO Q C, MA L Z, WANG J Q. Unified prediction model for the mechanical and electrical properties of high strength and high conductivity Cu matrix composite materials based on machine learning algorithms[J]. Foundry Technology, 2024, 45(1): 44-49.

[17] 李佩璇，王毅，隋旭东. 集成计算材料工程在固体润滑领域的应用[J]. 铸造技术，2023, 44(2): 132-146.
LI P X, WANG W Y, SUI X D. Review of ICME discovering advanced solid lubricants[J]. Foundry Technology, 2023, 44(2): 132-146.

[18] 周长璐，廖玮杰，唐斌，樊江昆，张平祥，袁睿豪. 蠕变断裂寿命预测方法研究进展[J]. 铸造技术，2022, 43(4): 245-252.
ZHOU C L, LIAO W J, TANG B, FAN J K, ZHANG P X, YUAN R H. Research progress on prediction methods of creep fracture life[J]. Foundry Technology, 2022, 43(4): 245-252.

[19] 邓钥丹，胡旺，连利仙，巩秀芳，刘颖，章语，王誉程. 数据驱动的镍基高温合金多目标优化设计与开发[J]. 铸造技术，2022, 43(5): 351-356.
DENG Y D, HU W, LIAN L X, GONG X F, LIU Y, ZHANG Y, WANG Y C. Data-driven multi-objective optimization design and development of Ni-base superalloy[J]. Foundry Technology, 2022, 43(5): 351-356.

[20] HAN J W, KAMBER M, PEI J. Data mining: Concepts and techniques[M]. Amsterdam: Elsevier Inc., 2012.

[21] 吴俊慷，鲁世强，邓莉萍，王天祥，王克鲁. Laves 相 $NbCr_2$/Nb 两相合金高温流动应力行为及本构关系建立[J]. 稀有金属材料与工程，2021, 50(7): 2541-2551.
WU J K, LU S Q, DENG L P, WANG T X, WANG K L. Thermal deformation behavior and constitutive relationship of laves phase $NbCr_2$/Nb dual-phase alloy[J]. Rare Metal Materials and Engineering, 2021, 50(7): 2541-2551.

[22] 邱仟，王克鲁，鲁世强，欧阳德来，崔霞，王俊. SP700 钛合金高温流动行为及本构关系[J]. 材料热处理学报，2021, 42(2): 145-151.
QIU Q, WANG K L, LU S Q, OUYANG D L, CUI X, WANG J. High temperature flow behavior and constitutive relationship of SP700 titanium alloy[J]. Transactions of Materials and Heat Treatment, 2021, 42(2): 145-151.

[23] 李全，金朝阳. 物理基本构模型和 BP 人工神经网络模型预测 AZ80 镁合金高温流动应力的比较研究[J]. 稀有金属材料与工程，2021, 50(11): 3924-3933.
LI Q, JIN C Y. Comparative study of physical-based constitutive model and BP artificial neural network model in predicting high temperature flow stress of AZ80 magnesium alloy[J]. Rare Metal

中国知网 https://www.cnki.net

Materials and Engineering, 2021, 50(11): 3924-3933.

[24] NAIR V, HINTON G E. Rectified linear units improve restricted Boltzmann machines [A]. Proceedings of the 27th International Conference on Machine Learning, ICML 2010 [C]. Haifa: IMLS, 2010. 807-814.

[25] DUGAS C, BENGIO Y, BÉLISLE F, NADEAU C, GARCIA R. Incorporating second-order functional knowledge for better option pricing [A]. Advances in Neural Information Processing Systems [C]. Denver, CO: Neural information processing systems foundation, 2001. 472-478.

(责任编辑:杨浩雪)

中国知网 https://www.cnki.net